

تخمین حدود پیش‌بینی بارش و رواناب مبتنی بر شبکه عصبی مصنوعی

الناز شرقی*^۱، ناردین جباریان پاک‌نژاد^۲

^۱ دانشیار دانشکده مهندسی عمران، دانشگاه تبریز

^۲ دانشجوی دکتری سازه‌های هیدرولیکی، دانشکده مهندسی عمران، دانشگاه تبریز

(دریافت: ۹۸/۳/۷، پذیرش: ۹۹/۸/۲۱، نشر آنلاین: ۹۹/۸/۲۱)

چکیده

در این مقاله پیش‌بینی نقطه‌ای و فواصل پیش‌بینی مدل شبکه عصبی مصنوعی (ANN) برای بارش و رواناب محاسبه شده است. سری زمانی ۲۸ و ۳۴ ساله از سال ۱۹۸۷ تا ۲۰۱۵ و ۱۹۸۱ تا ۲۰۱۵ به ترتیب برای حوضه رودخانه ليقوان چای و رودخانه غرب نیشناپوتنا (West Nishnabotna River) برای مدل‌سازی در مقیاس روزانه و ماهانه استفاده شده است. از آنجایی که پیش‌بینی نقطه‌ای ANN هیچ اطلاعاتی درباره عدم قطعیت مدل‌سازی بیان نمی‌کند، فواصل پیش‌بینی برای ارزیابی عملکرد ANN به کار گرفته شد. مدل‌سازی فواصل ساخته شده با روش تخمین حد بالا و پایین (LUBE) که در آن ANN با دو خروجی که نشان‌دهنده حد بالا و پایین هستند، برای تخمین حدود پیش‌بینی استفاده شد. همچنین روش کلاسیک بوت‌استرپ (Bootstrap)، که روشی رایج برای ارزیابی عدم قطعیت پیش‌بینی است، مورد استفاده قرار گرفت. نهایتاً دقت فواصل پیش‌بینی به وسیله دو معیار همگرایی فواصل پیش‌بینی و عرض فواصل کمیت‌سنجی شد. در این مطالعه، ورودی‌های مدل‌سازی با معیار غیرخطی اطلاعات مشترک انتخاب شدند. مقایسه بین نتایج دو روش حاکی از آن است که روش LUBE در مقایسه با روش بوت‌استرپ به نتایج قابل اطمینان‌تری منجر شد. احتمال همگرایی فواصل پیش‌بینی و عرض فواصل پیش‌بینی روش LUBE در مقایسه با روش بوت‌استرپ به ترتیب تا ۲۰٪ بیشتر و ۳۰٪ کم‌تر بود. در روش LUBE، مدل‌سازی در مقیاس روزانه در مقایسه با مقیاس ماهانه به ترتیب برای رواناب رودخانه ليقوان چای و رودخانه غرب نیشناپوتنا، احتمال همگرایی فواصل پیش‌بینی ۱۷٪ و ۱۳٪ بیشتر و عرض فواصل پیش‌بینی ۱۸٪ و ۱۲٪ کم‌تر بوده است.

کلیدواژه‌ها: بارش - رواناب، شبکه عصبی مصنوعی، فواصل پیش‌بینی، روش بوت‌استرپ.

۱- مقدمه

پدیده به داده‌های خروجی تبدیل می‌کنند، برای مدل‌سازی فرایندهایی با عدم قطعیت بالا بسیار مناسب می‌باشند. شبکه عصبی مصنوعی (ANN) ابزاری قدرتمند برای مدل‌های رگرسیون غیرخطی است و یکی از ابزارهای رایج برای تخمین رواناب به شمار می‌رود. توانایی ANN برای یادگیری و برنامه‌ریزی موجب مقبولیت و اقبال عمومی این ابزار توانمند گردیده است. ANN را می‌توان یک ساختار ریاضی که قادر به تشخیص ارتباط غیرخطی پیچیده بین داده‌های ورودی و خروجی است، توصیف کرد. در سال‌های اخیر ANN کاربرد زیادی در مدل‌سازی هیدرولوژیک داشته است (رجایی و همکاران، ۱۳۹۳؛ ندیری و همکاران، ۱۳۹۵). اما با وجود دقت قابل قبول مدل‌سازی انتقاد اساسی که این مدل‌ها با آن مواجه می‌شوند، شامل عدم شفافیت کافی و چالش در تفسیر خروجی، امکان بیش‌برازش و همچنین

یکی از چالش‌های اساسی در مسائل آب و مدیریت حوضه آبریز، محاسبه رواناب ناشی از بارش است. تخمین صحیح رواناب در موارد بسیاری مثل برنامه‌ریزی شهری، کاهش تأثیر سیلاب و تخریب محیط‌زیست، تغییر در سطح آب یا خشک‌سالی در منابع آب، نگهداری از زمین‌های کشاورزی و ذخیره یا آزادسازی مخازن بسیار مؤثر است. ارتباط بین بارش و رواناب، به دلیل مشخصات متعدد حوضه، تغییرات زمانی و مکانی پارامترهایی که بر روی رواناب به دلیل ناهمگونی حوضه‌ها وجود دارد، یکی از فرایندهای پیچیده هیدرولوژیک است. بنابراین مدل‌های هیدرولوژیک متعددی با درجه پیچیدگی متفاوت برای شبیه‌سازی فرایند تصادفی بارش - رواناب ایجاد شده‌اند. مدل‌های جعبه سیاه که داده‌های ورودی را بدون نیاز به هیچ اطلاعاتی درباره فرایند واقعی

۱. Artificial Neural Network

* نویسنده مسئول؛ شماره تماس: ۰۹۱۴۴۱۷۸۴۱۹

آدرس ایمیل: sharghi@tabrizu.ac.ir (ا. شرقی)، n.jabbarian@tabrizu.ac.ir (ن. جباریان پاک‌نژاد).

روش مستقل از اطلاعات درباره حد بالا و پایین PI و توزیع داده است. احتمال همگرایی روش LUBE بهتر از سایر روش‌ها می‌باشد و به‌طور مؤثر قادر به ایجاد توازن بین صحت و شرح دقت برای PI است (Khosravi و همکاران ۲۰۱۱). همچنین، زمان لازم برای ساخت PI، به‌طور قابل‌ملاحظه‌ای کوچک‌تر از سایر روش‌های ساخت PI است (Quan و همکاران، ۲۰۱۴). روش LUBE مبتنی بر ANN، برخلاف ANN کلاسیک که شامل یک خروجی به‌عنوان پیش‌بینی مدل می‌باشد، شامل دو خروجی است که نشان‌دهنده حد بالا و پایین پیش‌بینی هستند. هدف اصلی تعیین حدود پیش‌بینی کمک به تصمیم‌گیری و مدیریت مسائل مرتبط با کنترل رواناب است. بنابراین با اعمال PI، عدم قطعیت مرتبط با مدل‌سازی در نظر گرفته می‌شود و نتایج به‌دست‌آمده حاوی اطلاعات مهمی برای مدیریت، تصمیم‌گیری و طراحی مناسب می‌باشد. وقتی محدوده پیش‌بینی مشخص باشد، در حالتی که مسئله بحرانی است تصمیم‌گیری بدبینانه اعمال می‌شود و در نتیجه حد بالای پیش‌بینی پایه مدل‌سازی در نظر گرفته می‌شود اگرچه امکان دارد مدل‌سازی اقتصادی نباشد و در صورتی که تصمیم‌گیری خوش‌بینانه در نظر گرفته شود، حد پایین پیش‌بینی پایه مدل‌سازی می‌باشد؛ اگرچه با ریسک بالایی همراه است.

۲- مواد و روش‌ها

۲-۱- منطقه مورد مطالعه و داده‌ها

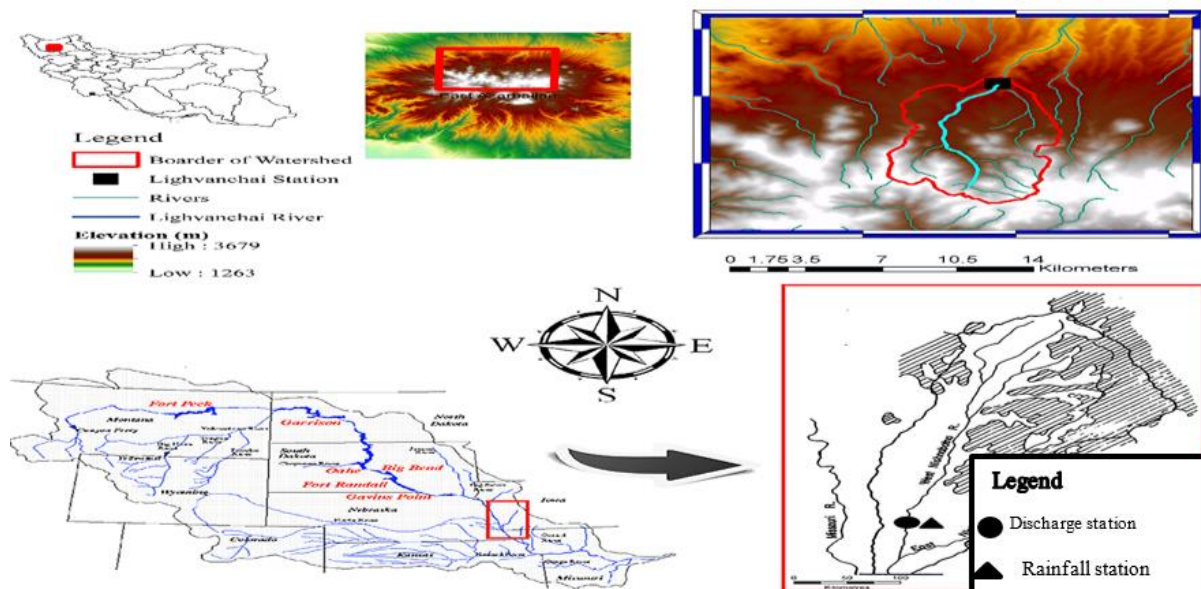
در این مطالعه داده‌ها از دو حوضه، رودخانه غربی نیشابوتنا (زیر حوضه رودخانه میسوری در ایالت متحده آمریکا) و ليقوان چای (زیرحوضه در ایران) با شرایط ژئومورفولوژی^۶ مختلف برای مدل‌سازی استفاده شدند (شکل (۱)). پارامترهای آماری مربوط به دو حوضه در جدول (۱) آورده شده است. اولین مجموعه داده برای حوضه ليقوان چای واقع در شمال غربی ایران در استان آذربایجان شرقی است و از شرکت توسعه آب و منابع انرژی گرفته شده است. داده‌ها از ایستگاه ليقوان، واقع در $37^{\circ} 50'$ عرض شمالی و $46^{\circ} 26'$ طول شرقی تهیه شده است. این حوضه یکی از زیرشاخه‌های رودخانه آجی‌چای است که به دریاچه ارومیه می‌ریزد. ليقوان چای در $37^{\circ} 43'$ و $37^{\circ} 50'$ عرض شمالی و $42^{\circ} 22'$ و $46^{\circ} 28'$ طول شرقی در شیب شمالی کوه سهند واقع شده است. ليقوان چای به‌عنوان زهکش اصلی حوضه بوده که با جهت‌گیری جنوبی-شمالی در ابتدا با نام باغچادره‌سی چای از نقاط و قله مرتفع کوه سهند مانند گبروه‌داغ (۳۵۹۶ متر)، کمال داغ (۳۲۳۶ متر)، شرشرداغ و غیره سرچشمه می‌گیرد. در طول مسیرآبراهه‌های متعددی از جمله توله‌سرچای و بارالی چای به آن

عدم بیان دقت پیش‌بینی و خطای مدل در پیش‌بینی ANN می‌باشد. بنابراین کمیت‌سنجی عدم قطعیت پیش‌بینی بسیار حائز اهمیت است. از جمله ابزار رایج در تعیین عدم قطعیت، فواصل پیش‌بینی (PI)^۲ هستند. از روش‌های کلاسیک تعیین PI می‌توان به روش دلتا و بایاسین^۳ اشاره کرد. روش دلتا بر اساس ارائه و تفسیر ANN به‌عنوان مدل رگرسیون غیرخطی و به‌کارگیری تئوری تقریبی استاندارد برای ساخت PI است (Chryssoulouris و همکاران، ۱۹۹۶). در این روش PI، بر فرض این‌که خطا همگن بوده و از توزیع نرمال پیروی می‌کند، ساخته می‌شود که محدودیت روش دلتا در نظر گرفته می‌شود. روش بایاسین بر اساس آمار بایاسین، برای بیان عدم قطعیت وزن‌های شبکه در ترم توزیع احتمال و ادغام آن‌ها برای به‌دست آوردن توزیع احتمال خروجی ANN است (Mackay، ۱۹۹۲). روش بایاسین نیازمند انتگرال مونت کارلو^۴ بر روی فضای وزن‌ها است، بنابراین برای کاربرد چندبعدی دنیای واقعی نامناسب است. بنابراین، این روش‌ها دارای محاسبات پیچیده ریاضی و فرضیات محدودکننده درباره توزیع داده‌ها می‌باشند. روش بوت‌استرپ یکی دیگر روش‌های شبیه‌سازی مبتنی بر داده است که با باز نمونه‌گیری داده‌ها و آموزش زیرمجموعه‌ای از کل داده‌ها به تعیین PI می‌پردازد. این روش یک روش رایج و آسان است که به هیچ‌گونه فرضیاتی درباره توزیع داده‌ها نیاز ندارد. از این روش در مطالعاتی در زمینه هیدرولوژی استفاده شده است.

Chatterjee و Tiwari (۲۰۱۰) عدم قطعیت پیش‌بینی سیل به‌وسیله ANN را با روش بوت‌استرپ تعیین کردند و اظهار داشتند که این روش قادر به حل مشکل بیش‌برازش در ANN می‌باشد. Sudheer و Kasiviswanathan (۲۰۱۳) با استفاده از روش بوت‌استرپ عدم قطعیت جریان رودخانه‌ای واقع در آمریکا را بررسی کرده و با دو معیار همگرایی و عرض PI، به کمیت‌سنجی PI پرداختند.

Kumar و همکاران (۲۰۱۵) با استفاده از روش بوت‌استرپ به ارزیابی عدم قطعیت جریان مخزن پرداختند و به این نتیجه دست یافتند که به‌جای پیش‌بینی نقطه‌ای در نظر گرفتن محدوده پیش‌بینی، قابل‌اطمینان‌تر، دقیق‌تر و در کارهای عملی مؤثرتر می‌باشد. در این مطالعه، روش تخمین حد بالا و پایین (LUBE) که اولین بار توسط Khosravi و همکاران (۲۰۱۰) پیشنهاد شده است و روش نوین برای ساخت PI در زمینه هیدرولوژی است، به‌کار گرفته شده است. از این روش در برخی مطالعات گذشته در زمینه هیدرولوژی و هیدروکلماتولوژی^۵ استفاده شده است (Chau و Taormina، ۲۰۱۵، Nourani و همکاران ۲۰۱۹). این

می‌پیوندد. رژیم رودخانه برفی بوده (عمده جریان رودخانه ناشی از ذوب برف می‌باشد) و به همین جهت این حوضه آبریز دارای شاخه‌بندی مشخص و کم تراکمی می‌باشد.



شکل ۱- نقشه مناطق مورد مطالعه: الف) ليقوان چای، ب) رودخانه غرب نيشناپوتنا

جدول ۱- پارامترهای آماری سری زمانی مشاهداتی حوضه در دوره ۱۹۸۷ تا ۲۰۱۵ و ۱۹۸۱ تا ۲۰۱۵ به ترتیب برای حوضه ليقوان چای

حوضه				پارامترهای آماری	سری زمانی	مقیاس
نیشناپوتنا		لیقوان چای				
واسنجی	صحت‌سنجی	واسنجی	صحت‌سنجی			
۰/۸۶	۱/۰۵	۲/۲۵	۲/۵۶	میانگین	بارش (میلی‌متر)	روزانه
۴۸/۲	۴۰/۷	۱۹۲/۰۰	۱۰۴/۱۰	ماکسیمم		
۰	۰	۰	۰	مینیمم		
۲/۷۴	۳/۰۸	۷/۴۰	۸/۲۸	انحراف معیار	رواناب (میلی‌متر)	روزانه
۳/۲	۲/۹۳	۳/۲۹	۳/۲۳	ضریب تغییرات		
۰/۷۷۱	۰/۸۲۵	۲۱/۰۲	۲۸/۳۹	میانگین		
۸/۶۵۰	۶/۰۵۰	۷۳۰/۵۷	۶۵۴/۱۲	ماکسیمم	رواناب (میلی‌متر)	روزانه
۰/۰۱	۰/۰۱۰	۱/۳۰	۲/۶۳	مینیمم		
۰/۸۵۲	۰/۸۹۰	۳۱/۷۶	۳۶/۳۰	انحراف معیار		
۱/۱۰۴	۱/۰۸۰	۱/۵۱	۱/۲۸	ضریب تغییرات	بارش (میلی‌متر)	روزانه
۲۶/۵۴	۳۱/۳۸	۶۸/۵۸	۷۸/۰۸	میانگین		
۱۰۹	۱۳۱/۱	۲۹۱/۶۰	۳۲۰/۵۰	ماکسیمم		
۰	۰	۰	۰	مینیمم	بارش (میلی‌متر)	روزانه
۲۴/۰۴	۳۰/۳۰	۵۴/۹۱	۷۰/۳۷	انحراف معیار		
۰/۹	۰/۹۶	۰/۸۰	۰/۹۱	ضریب تغییرات		
۲۳/۴۶۹	۲۵/۲۸۸	۶۴۱/۵۳	۸۵۹/۶۵	میانگین	رواناب (میلی‌متر)	ماهانه
۱۶۱/۴۶۰	۱۱۳/۰۰۰	۵۵۸۰/۱۲	۵۱۰۵/۸۱	ماکسیمم		
۳/۹۰۰	۳/۵۰۹	۵۶/۸۶	۱۲۳/۰۷	مینیمم		
۲۳/۷۹	۲۴/۱۳۶	۶۵۷/۶۴	۸۲۹/۰۸	انحراف معیار	رواناب (میلی‌متر)	ماهانه
۱/۰۰۸	۰/۹۵۴	۱/۰۳	۰/۹۶	ضریب تغییرات		

غیرخطی را دارند به‌عنوان ورودی ANN انتخاب شده‌اند. آنتروپی و اطلاعات مشترک از جنس اطلاعات هستند و معیار آماری میزان تصادفی بودن و عدم قطعیت در توزیع احتمال است. این معیار به‌عنوان معیار بی‌نظمی، آشفتگی و عدم قطعیت است. در حالت کلی، مقدار تئوری اطلاعات شانون^۸ در حالت گسسته و پیوسته بر اساس داده و طبیعت مسئله است. داده‌های استفاده‌شده در این مطالعه گسسته می‌باشد. اگر از بین چند متغیر لازم باشد که تعدادی به‌عنوان ورودی یک مدل برگزیده شوند و در این راه هیچ معیاری در دست نباشد، گزینش متغیرهایی که آنتروپی و یا اطلاعات بالاتری داشته باشند معقول به‌نظر می‌رسد. آنتروپی، یک معیار بدون در نظر گرفتن رابطه بین ورودی و خروجی مدل و فقط براساس ویژگی‌های ورودی تعریف می‌شود اما نظریه آنتروپی، MI را به‌عنوان یک معیار بر اساس رابطه بین ورودی و خروجی مدل تعریف می‌کند.

MI دو متغیر تصادفی میزان وابستگی غیرخطی دو متغیر را اندازه‌گیری می‌کند (Yang و همکاران، ۲۰۰۰). MI با مقدار بیشتر حاکی از همبستگی غیرخطی زیاد، MI کم حاکی از عدم ارتباط غیرخطی است و MI صفر بین دو متغیر تصادفی نشان‌دهنده آن است که متغیرها مستقل از هم هستند. MI به‌صورت رابطه (۲) محاسبه می‌شود:

$$MI(X,Y)=H(X)+H(Y)-H(X,Y) \quad (2)$$

که $H(X)$ و $H(Y)$ به‌ترتیب، آنتروپی X و Y هستند و $H(X,Y)$ آنتروپی مشترک X و Y است (Shannon, ۱۹۴۸) و به‌صورت رابطه (۴) محاسبه می‌شود. آنتروپی شانون برای متغیر تصادفی X با طول n و مقادیر (X_n, \dots, X_2, X_1) و احتمال‌های متناظر (P_2, P_1, \dots, P_n) به‌صورت فرمول (۳) محاسبه می‌شود (Gao و همکاران، ۲۰۰۸):

$$H(x) = \sum_{i=1}^n P(X_i) \log[P(X_i)] \quad (3)$$

$$H(X,Y) = -\sum_{i=1}^n \sum_{j=1}^n P(X_i, Y_j) \log[P(X_i, Y_j)] \quad (4)$$

می‌توان گفت که معیار MI، به جهت نظارت‌شده بودن مشابه ضریب همبستگی خطی است با این تفاوت که MI ماهیتی غیرخطی و ضریب همبستگی ساختاری خطی دارد. در این مطالعه برای انتخاب ورودی‌های مؤثر، MI بین سری زمانی خروجی (رواناب) و سری زمانی بارش و رواناب با ۱۵ روز تأخیر و ۲۰ ماه تأخیر به‌ترتیب برای مدل‌سازی در مقیاس روزانه و ماهانه محاسبه شد و از بین آن‌ها سری‌های زمانی با بیشترین MI انتخاب شدند.

این حوضه دارای اقلیم نیمه‌خشک سرد می‌باشد، که به‌سمت ارتفاعات به اقلیم نیمه مرطوب سرد تغییر پیدا می‌کند. مساحت ناحیه تقریباً ۱۴۲ کیلومترمربع است. عرض حوضه بین ۱۲۶۳ و ۳۶۷۹ متر تغییر می‌کند. طول رودخانه در ایستگاه ليقون، ۲۸/۵ کیلومتر است و دارای جریان دائمی است. منطقه مورد مطالعه دوم رودخانه غربی نیشناپوتنا یکی از زیر حوضه رودخانه میسوری در ایالت متحده آمریکا است. بارش بهار و دما و میزان بارش در زمستان تحت تأثیر تغییرات جریان از اقیانوس آرام نقش مهمی در تغییرات تأمین آب سطحی در حوضه بالادست ایفا می‌کند. جریان حوضه پایین به‌طور قابل‌توجهی با بارش در اواخر بهار و اوایل تابستان در ارتباط است. داده‌ها در مقیاس روزانه و ماهانه از سایت waterwatch.usgs.gov و ایستگاه Harlan IA US و Randolph به‌ترتیب در طول غربی ۳۱' ۹۵° و ۳۴' ۹۵° عرض شمالی ۶۰' ۴۱° و ۵۲' ۴۰° گرفته شده است. رودخانه در طول و عرض جغرافیایی ۱۰' ۱۱۱° غربی و ۴۱' ۵۱° شمالی واقع شده است. بیش‌ترین طول رودخانه در ایستگاه Randolph حدود ۱۹۰ کیلومتر می‌باشد. مساحت کل حوضه ۷۶۰۰ کیلومترمربع است.

۲-۲- انتخاب ورودی

مدل‌سازی رواناب حوضه به‌طور عمده از سری زمانی بارش-رواناب متأثر می‌باشد. بنابراین ارتباط آن‌ها به‌صورت رابطه (۱) بیان می‌شود (Hagan و Menhaj، ۱۹۹۴؛ Riad و همکاران، ۲۰۰۴).

$$Q(t) = F[R(t), R(t-\Delta t), \dots, R(t-n_x \Delta t), Q(t-\Delta t), \dots, Q(t-n_y \Delta t)] \quad (1)$$

که R بیان‌کننده بارش، Q بیان‌کننده رواناب در خروجی حوضه، F هر نوع ساختار مدل و t فواصل نمونه‌گیری داده و n_x و n_y اعداد صحیح مثبت که در طول حافظه حوضه تأثیر می‌گذارد. با توجه به رفتار پیچیده سری‌های زمانی هیدرولوژیک مثل بارش-رواناب، ممکن است بین ورودی و خروجی ارتباط خطی یا غیرخطی حاکم باشد. برای فرایند غیرخطی با مدل غیرخطی ممکن است ارتباط خطی ضعیف و ارتباط غیرخطی قوی بین ورودی و خروجی باشد (Nourani و همکاران، ۲۰۱۵). بنابراین در این مطالعه برای انتخاب ورودی‌های مهم و تأثیرگذار در مدل‌سازی بارش رواناب، روش غیرخطی اطلاعات مشترک (MI)^۹ به‌کار گرفته شده است. به‌نحوی که سری‌های زمانی بارش رواناب (با زمان‌های تأخیر مختلف) که بیشترین مقدار اطلاعات مشترک و همبستگی


باشد، برای مقایسه PI می‌توان MPIW را به‌صورت فرمول (۱۰) نرمال کرد:

$$NMPIW = MPIW/R \quad (10)$$

که R دامنه داده‌ها است. NMPIW، مقیاس بی‌بعدی است که نشان‌دهنده میزان باریک بودن PI است.

۲-۴-۲ PI ساخته شده با استفاده از روش LUBE

ساختار ANN با دو خروجی برای تخمین حد بالا و پایین PI با روش LUBE در شکل (۲) نشان داده شده است. اولین خروجی متناظر با حد بالا و دومی نشان‌دهنده حد پایین است. در گام اول داده‌ها به دو دسته واسنجی و صحت‌سنجی تقسیم می‌شوند و سپس ANN با دو خروجی آموزش داده می‌شوند می‌توان به‌عنوان حدس اولیه، مقادیر خروجی را ± 0.5 مقادیر مشاهداتی برای آموزش ANN در نظر گرفته و وزن‌های متناظر پیدا شوند. سپس وزن‌ها به‌صورت تصادفی، حول حدس اولیه، برای تولید مجموعه وزن‌های جدید تغییر داده می‌شود. طبق گزارش Dhanesh و Sudheer (۲۰۱۰) وزن‌های ANN در محدوده ± 0.1 مقدار واسنجی، حساس هستند. بنابراین ANN‌های جدید با مجموعه متعددی از وزن‌های تغییر یافته شده (در محدوده ± 0.1 وزن‌های اولیه) ایجاد می‌شوند و ANN‌ها با این مجموعه وزن‌ها شبیه‌سازی می‌شوند تا مجموعه مختلف PI به‌دست آید. در این مطالعه، تعداد مجموعه وزن‌های تولیدشده که بستگی به تعداد نرون‌های ^{۱۴} لایه میانی دارد، در محدوده ۷۰۰ تا ۱۲۰۰ در نظر گرفته شده است. مجموعه PI‌ای که منجر به بیش‌ترین PICP و کم‌ترین NMPIW می‌شود، سرانجام به‌عنوان نتیجه نهایی در نظر گرفته می‌شود. در ارزیابی شبکه، اول PICP بررسی می‌شود، اگر کم‌تر از مقدار سطح اطمینان در نظر گرفته شده باشند (در این مطالعه ۰.۹۰)، شبکه موردنظر کنار گذاشته می‌شود.



12. Prediction Interval Coverage Probability
13. Mean Prediction Interval Width
14. Neurons

۲-۳-۲ معیارهای ارزیابی

۲-۳-۲-۱ ارزیابی پیش‌بینی نقطه‌ای

به‌منظور ارزیابی عملکرد پیش‌بینی نقطه‌ای ANN، معیار نش ساتکلیف (NSE) ^۱ و ریشه متوسط مجذور خطا (RMSE) ^{۱۰} و ضریب همبستگی (CC) ^{۱۱} استفاده شده‌اند که به‌ترتیب مطابق روابط (۵)، (۶) و (۷) محاسبه می‌شوند.

$$NSE = 1 - \frac{\sum_{i=1}^N (R_i - Z_i)^2}{\sum_{i=1}^N (P_i - \bar{P})^2} \quad (5)$$

$$RMSE = \sqrt{\frac{\sum_{i=1}^N (P_i - Z_i)^2}{N}} \quad (6)$$

$$R = \frac{\sum (P - \bar{P}) \cdot \sum (Z - \bar{Z})}{\sqrt{\sum (P - \bar{P})^2 \sum (Z - \bar{Z})^2}} \quad (7)$$

که P_i و Z_i به‌ترتیب i امین مقدار پیش‌بینی شده و i امین مقدار مشاهده شده و \bar{P} میانگین پیش‌بینی‌شونده و N تعداد کل مشاهدات است.

۲-۳-۲-۲ معیارهای ارزیابی PI

دو معیار ارزیابی کمی PI، احتمال همگرایی PI (PICP) ^{۱۲} و متوسط عرض PI (MPIW) ^{۱۳} است. PICP درصدی از داده‌های مشاهداتی است که در بازه پیش‌بینی می‌افتد. هرچه عرض PI گسترده‌تر باشد، مقادیر مشاهداتی بیشتری را پوشش می‌دهد. اگر PICP به مقدار تعیین شده متناظر با سطح اطمینان نزدیک‌تر باشد، قابل‌اطمینان‌تر است (Khosravi و همکاران، ۲۰۱۰؛ Kasiviswanathan و Sudheer، ۲۰۱۶). مقدار PICP به‌صورت رابطه (۸) محاسبه می‌شود:

$$CP = \begin{cases} 1 & L(X_i) < x_i < U(X_i) \\ 0 & \text{else} \end{cases} \rightarrow c_i = 1 \quad (8)$$

عملاً، PI که بسیار گسترده است، هیچ اطلاعاتی درباره PI نمی‌دهند، به همین دلیل مقیاس دیگری نیاز است تا بتواند عرض PI را کمی‌سنجی کند. میانگین عرض PI به‌صورت فرمول (۹) تعریف می‌شود:

$$MPIW = \frac{1}{n} \sum_{i=1}^n L(X_i) - U(X_i) \quad (9)$$

که $L(X_i)$ و $U(X_i)$ به‌ترتیب حد بالا و پایین حدود پیش‌بینی متناظر با i امین نمونه است. اگر عرض داده‌های خروجی معلوم

9. Nash Sutcliffe Efficiency
10. Root Mean Square Errors
11. Correlation Coefficient

ساخت PI پیش‌بینی برای مشاهدات آینده X با احتمال P در توزیع نرمال، با میانگین انحراف معیار مشخص، طبق معادله (۱۳) و (۱۴) خواهیم داشت:

$$P(l < X < u) = P\left(\frac{l - \hat{y}_{boot}}{\hat{\sigma}_{boot}} < \frac{X - \hat{y}_{boot}}{\hat{\sigma}_{boot}} < \frac{u - \hat{y}_{boot}}{\hat{\sigma}_{boot}}\right) \quad (13)$$

مقادیر مختلف مطابق با Z و سطوح اطمینان مختلف در جدول (۲) نشان داده شده است. که $Z = \frac{X - \hat{y}_{boot}}{\hat{\sigma}_{boot}}$ مقدار استاندارد X ، که از توزیع نرمال استاندارد تبعیت می‌کند (Grant و Leavenworth، ۱۹۷۲).

$$\frac{l - \hat{y}_{boot}}{\hat{\sigma}_{boot}} = -Z \quad ; \quad \frac{u - \hat{y}_{boot}}{\hat{\sigma}_{boot}} = Z \quad \text{یا} \quad (14)$$

$$l = \hat{y}_{boot} - Z\hat{\sigma}_{boot} \quad ; \quad u = \hat{y}_{boot} + Z\hat{\sigma}_{boot}$$

جدول ۲- مقادیر Z برای PI مختلف

Z	PI
۱/۱۵	٪۷۵
۱/۶۴	٪۹۰
۱/۹۶	٪۹۵
۲/۵۸	٪۹۹

۳- نتایج و بحث

با توجه به ورودی‌های انتخاب شده که در جدول (۳) آورده شده است در نظر گرفتن سری زمانی بارش به‌تنهایی به‌عنوان ورودی ANN در مدل‌سازی بارش رواناب نتایج مورد قبولی نداشت، اما ترکیب سری زمانی رواناب با سری زمانی بارش به‌عنوان ورودی ANN منجر به بهبود نتایج شد و سری زمانی بارش با یک روز تأخیر بیشترین ارتباط غیرخطی را در مقایسه با تأخیرهای دیگر سری‌های زمانی بارش داشت. اما سری زمانی رواناب با تأخیرهای مختلف دارای مقادیر MI یکسانی بودند به‌همین دلیل برای انتخاب مناسب‌ترین ورودی تحلیل حساسیت انجام گرفت. به‌دلیل این که تابع فعال‌سازی ANN در بازه ۱- تا ۱ حساس است، داده‌ها نرمال شدند و به‌منظور واسنجی و صحت‌سنجی مدل، داده‌ها به دو قسمت تقسیم شدند که ۷۵٪ از داده‌ها برای آموزش ANN و ۲۵٪ برای صحت‌سنجی استفاده شدند. بنابراین بازه ۱۹۸۷-۲۰۰۸ و ۱۹۸۱-۲۰۰۶ به‌ترتیب برای آموزش دو حوضه ليقوان‌چای و نیشابوتا^{۱۵} و بازه ۲۰۰۸-۲۰۱۵ و ۲۰۰۶-۲۰۱۵ برای صحت‌سنجی استفاده شدند.


ANN پیشرو^{۱۶} با سه‌لایه بازگشتی^{۱۷} و با الگوریتم لونیگ-مارکواریت^{۱۸} تابع فعال‌سازی سیگموئید^{۱۹} برای مدل‌سازی در نظر گرفته شد و برای تشخیص ساختار بهینه ANN تعداد لایه‌های

شکل ۲- مدل ANN برای تخمین حد بالا و پایین PI (Quan و همکاران، ۲۰۱۴)

اگر PICP بیشتر یا مساوی مقدار تعیین‌شده سطح اطمینان باشد، NMPIW با مقدار NMPIW که بهینه در نظر گرفته شده است، مقایسه می‌شود اگر کم‌تر بود با ANN جدید جایگزین می‌شود. این روند ادامه پیدا می‌کند تا همه شبکه‌ها بررسی شوند.

۲-۵- روش بوت‌استرپ

روش بوت‌استرپ در سال ۱۹۹۳ توسط Tibshirani و Efron (۱۹۹۳) پیشنهاد داده شد که از بازنمونه‌گیری و جابه‌جایی داده‌ها و آموزش زیرمجموعه داده‌های کلی، برای تولید مدل متفاوت و آموزش شبکه به‌صورت منحصر برای هر زیرمجموعه به‌جای داده‌های اصلی عمل می‌کند (مراجعه شود به شکل (۳)). از جمله فواید استفاده از روش بوت‌استرپ می‌توان به این مورد اشاره کرد که به هیچ فرضیاتی برای توزیع احتمال داده‌ها و یا توابع غیرخطی پیچیده نیاز ندارد. اگر نمونه‌های تصادفی در روند بوت‌استرپ از داده‌های کلی در دسترس قرار گیرند، میانگین پیش‌بینی \hat{y}_{boot} به‌عنوان خروجی مدل متناظر با i امین ورودی X است.



شکل ۳- شماتیک روش بوت‌استرپ (Z_{i0} ، ۲۰۰۶)، PI متناظر با زیرمجموعه داده‌ها برای آموزش

میانگین و واریانس خروجی‌ها این شبکه از معادله پیشرو برای محاسبه PI از رابطه (۱۱) و (۱۲) استفاده می‌شود:

$$\hat{y}_{boot}(x) = \frac{1}{B} \sum_{b=1}^B f(x_i; P_b) \quad (11)$$

$$\hat{\sigma}_{boot}^2(x) = \frac{1}{B-1} \sum_{b=1}^B (f(x_i; P_b) - \hat{y}_{boot}(x))^2 \quad (12)$$

که P_b نشان‌دهنده نمونه به‌دست‌آمده از b امین پارامتر بوت‌استرپ است و f نشان‌دهنده فرم تابعی مدل ANN است. برای

18. Levenberg marquardt
19. Sigmoid

15. Nishnabotna
16. Feed forward
۱۷. Back propagation

است عملکرد بهتری نسبت به مدل‌هایی که ورودی آن‌ها ترکیب سری زمانی بارش و رواناب است، دارند. این شاید به دلیل طبیعت تصادفی و توزیع نامنظم بارش در ناحیه باشد. همان‌طور که در جدول (۳) نشان داده شده است، مدل‌سازی در مقیاس روزانه عملکرد بهتری دارد و NSE سری زمانی صحت‌سنجی به ترتیب برای حوضه ليقوان چای و رودخانه نيشناپوتا تا ۱۰٪ تا ۱۵٪ بیشتر از مقیاس ماهانه است.

میانمی و تکرار با آزمون وخطا انتخاب شدند. بالاخره عملکرد مدل با استفاده از معیار R و NSE و RMSE مورد ارزیابی قرار گرفت و نتایج در جدول (۳) نشان داده شده است.

همان‌طور که در جدول (۳) نشان داده شده است، در مقیاس روزانه ANN مدل ۲ و ۴ NSE بیشتری در حدود ۱۲٪ و ۱۴٪ در مقایسه با ANN مدل ۱ و ۳ دارد. این نتایج حاکی از آن است که برای مدل‌هایی که ورودی‌هایشان فقط شامل سری زمانی رواناب

جدول ۳- نتایج پیش‌بینی نقطه‌ای دو حوضه در هر دو مقیاس

مقیاس	حوضه	ANN	ورودی	*RMSE صحت‌سنجی	*RMSE واسنجی	R صحت‌سنجی	R واسنجی	NSE صحت‌سنجی	NSE واسنجی
روزانه	ليقوان چای	۱	$I_t, Q_{t-1}, Q_{t-2}, Q_{t-3}$	۰/۰۱	۰/۰۰۷	۰/۸۴	۰/۹	۰/۷۲	۰/۸۱
	غرب رودخانه نيشناپوتا	۲	$Q_{t-10}, Q_{t-2}, Q_{t-3}$	۰/۰۳	۰/۰۲	۰/۹۵	۰/۹۶	۰/۹	۰/۹۳
		۳	I_t, Q_{t-1}, Q_{t-2}	۰/۰۳	۰/۰۲	۰/۷۵	۰/۷۵	۰/۵۴	۰/۵۶
		۴	$Q_{t-1}, Q_{t-2}, Q_{t-3}, Q_{t-4}, Q_{t-5}$	۰/۰۳	۰/۰۲	۰/۸۳	۰/۸۴	۰/۷	۰/۷
ماهانه	ليقوان چای	۵	$I_{t-1}, Q_{t-1}, Q_{t-2}$	۰/۰۸	۰/۰۷	۰/۸	۰/۸۴	۰/۶۴	۰/۷۱
	غرب رودخانه نيشناپوتا	۶	$Q_{t-1}, Q_{t-2}, Q_{t-3}, Q_{t-12}, Q_{t-13}$	۰/۰۸	۰/۰۵	۰/۸	۰/۹۲	۰/۶۶	۰/۸۴
		۷	$I_{t-1}, Q_{t-1}, Q_{t-2}$	۰/۱	۰/۰۸	۰/۶۹	۰/۶۷	۰/۵	۰/۵۵
		۸	$Q_{t-1}, Q_{t-2}, Q_{t-12}, Q_{t-13}$	۰/۱	۰/۰۸	۰/۷	۰/۶۹	۰/۵	۰/۵

* مقادیر RMSE نرمال شده و بدون واحد می‌باشند.

همکاران، ۲۰۰۲؛ Imrie و همکاران، ۲۰۰۰؛ Srivastav و همکاران، ۲۰۰۷). علت این عملکرد نامناسب شاید به دلیل تعداد ناکافی نقاط اوج در آموزش ANN باشد. به علاوه، در مدل‌های به هم پیوسته با توجه به ویژگی‌های مارکوف^۲، گام‌های زمانی آتی با استفاده از گام‌های زمانی قبلی پیش‌بینی می‌شود به همین دلیل نقاط اوج رواناب کم برآورد می‌شود زیرا نیروی خارجی ناگهانی به سیستم اعمال می‌شود (Sharghi و همکاران، ۲۰۱۹).





با توجه به این که پیش‌بینی نقطه‌ای ANN هیچ اطلاعاتی درباره دقت پیش‌بینی نمی‌دهد و ارزیابی قابلیت اطمینان پیش‌بینی بسیار حائز اهمیت می‌باشد، در این مطالعه، PI با دو روش بوت‌استرپ و LUBE محاسبه گردید. عملکرد کلی هر روش ساخت PI برای مدل‌سازی مبتنی بر ANN به ساختار شبکه و روند آموزش بستگی دارد. برای ایجاد بهترین نتایج، تعداد نرون‌های بهینه با روش آزمون وخطا تعیین شدند. تعداد نرون‌ها از ۱ تا ۱۲ نرون با استفاده از آزمون وخطا تعیین شدند. سطح اطمینان متناظر با تمام فواصل ۹۰٪ می‌باشد. دو معیار PICP (معادله (۸)) و NMPIW (معادله (۱۰)) برای هر مجموعه وزن‌ها محاسبه شدند (با تغییر وزن‌های اولیه)، تا ساختار بهینه ANN برای ساخت PI با بیش‌ترین PICP کم‌ترین NMPIW به دست آید. مقادیر بهینه به دست آمده PICP و NMPIW در جدول (۴) نشان داده شده است. همان‌طور که در جدول (۴) نشان داده شده است مقدار PICP برای

نتایج حاصل از با برخی نتایج مطالعات گذشته از جمله (Nourani و همکاران، ۲۰۱۱) هم‌خوانی دارد. به علاوه تعداد نمونه‌های استفاده شده برای مقیاس روزانه خیلی بیشتر از ماهانه می‌باشد. برای حوضه ليقوان چای و نيشناپوتا تعداد نمونه به ترتیب در بازه ۲۸ و ۴۰ ساله، ۷۵۶ و ۴۸۰ برای مقیاس ماهانه و ۲۲۹۹۵ و ۱۴۶۰۰ برای مقیاس روزانه است. بنابراین تعداد نمونه‌های مقیاس روزانه ۳۰ برابر مقیاس ماهانه است که باعث بهبود عملکرد آن می‌شود. همچنین ANN در حوضه ليقوان چای در هر دو مقیاس روزانه و ماهانه عملکرد بهتری نسبت به حوضه رودخانه نيشناپوتا دارد. معیار NSE برای داده‌های صحت‌سنجی حوضه ليقوان چای به ترتیب تا ۲۰٪ و ۲۶٪ بیشتر از حوضه رودخانه نيشناپوتا در مقیاس ماهانه و روزانه است. عملکرد نامناسب ANN در این حوضه احتمالاً به دلیل الگوی بسیار متغیر بارش و آب‌وهوا در این حوضه و مساحت زیاد حوضه رودخانه نيشناپوتا در مقایسه با حوضه ليقوان چای می‌باشد. نتایج صحت‌سنجی برای سری زمانی خروجی مدل ANN (مدل ۲، ۴، ۶، ۸) با استفاده از پیش‌بینی نقطه‌ای و PI ساخته شده، در شکل (۴) نشان داده شده است. همان‌طور که در شکل (۴) دیده می‌شود، با وجود عملکرد مناسب ANN، پیش‌بینی نقطه‌ای ANN در برخی نقاط مخصوصاً حوضه رودخانه نيشناپوتا قادر به پیش‌بینی نقاط اوج نمی‌باشد. ضعف ANN در تخمین نقاط اوج در برخی مطالعات بیان شده است (Sudheer و

گرفته شد و نتایج حاصل از دو روش با هم مقایسه شدند. بنابراین ANN ۸۰ بار، با استفاده از نمونه‌های انتخاب‌شده تصادفی به تعداد ۴۸۵، ۱۰۲۲۷۰، ۳۳۵، ۱۴۱۱، ۱۶۶، ۲۴۲، ۵۱۱۴، ۷۴۴۰ نمونه برای رودخانه نیشناپوتنا و ليقوان چای، به ترتیب برای مقیاس روزانه و ماهانه آموزش داده شد. وزن‌های آموزش داده‌شده برای شبیه‌سازی خروجی ANN با نمونه‌های داده‌های کلی به کار برده شد. سپس برای ساخت PI، میانگین و انحراف معیار خروجی‌ها با سطح اطمینان ۹۰٪ برای ایجاد حد بالا و پایین همانند معادله‌های (۱۳) و (۱۴) استفاده شده و خروجی‌های به‌دست‌آمده در جدول (۴) نشان داده شده است.

تخمین مقیاس روزانه تا ۲۹٪ و ۱۸٪ به ترتیب بیشتر از تخمین ماهانه برای ليقوان چای و رودخانه نیشناپوتنا است. NMPIW برای مقیاس ماهانه تا ۲۰٪ و ۱۷٪ به ترتیب کم‌عرض‌تر از مدل‌سازی روزانه ليقوان چای و رودخانه نیشناپوتنا است و نتایج به‌دست‌آمده برای PI متناظر با نتایج پیش‌بینی نقطه‌ای بوده است. بنابراین طول مجموعه داده‌ها در آموزش ANN نقش مهمی در عملکرد PI داشته است.

در مقیاس روزانه PICP برای حوضه ليقوان چای تا ۹٪ بیشتر از رودخانه نیشناپوتنا بوده، اما در مقیاس ماهانه دو حوضه عملکرد تقریباً مشابهی داشتند. در ادامه برای ارزیابی مقادیر PI به‌دست‌آمده روش کلاسیک بوت‌استرپ نیز برای ایجاد PI به کار



شکل ۴- نتایج صحت‌سنجی برای پیش‌بینی نقطه‌ای و PI‌های ساخته‌شده: الف) حوضه ليقوان چای در مقیاس ماهانه، ب) ليقوان چای در مقیاس روزانه، ج) رودخانه غرب نیشناپوتنا در مقیاس ماهانه، د) رودخانه غرب نیشناپوتنا در مقیاس روزانه

جدول ۴- نتایج PI‌های ایجادشده برای دو حوضه با روش LUBE و بوت‌استرپ

LUBE		بوت‌استرپ		ANN	مقیاس
PICP	NMPIW	PICP	NMPIW		
۰/۸۶	۰/۰۴	۰/۶	۰/۰۹	۱	روزانه
۰/۹۳	۰/۲۵	۰/۸۹	۰/۱۱	۲	
۰/۸۸	۰/۰۵	۰/۷۷	۰/۰۳	۳	
۰/۷۴	۰/۰۴	۰/۷۲	۰/۰۲	۴	
۰/۶۹	۰/۱۷	۰/۶	۰/۱۹	۵	
۰/۵۶	۰/۱	۰/۸۳	۰/۳	۶	ماهانه
۰/۷	۰/۱۷	۰/۵۱	۰/۱۱	۷	

همان‌طور که در جدول (۴) دیده می‌شود، مقادیر PICP برای مدل ۱ و ۶ تا ۳۰٪ و ۲۳٪ به ترتیب بیشتر از مدل ۵ و ۱ است که در آن سری زمانی رواناب مستقلاً به‌عنوان ورودی ANN استفاده شده است. همچنین با توجه به جدول (۴) در بیشتر حالت‌ها PICP حوضه ليقوان چای تا ۱۷٪ در مقایسه با حوضه نیشناپوتنا بیشتر بوده است. به‌علاوه در هر دو حوضه در مقیاس روزانه مقادیر PICP تا ۳۸٪ بیشتر و NMPIW تا ۱۱٪ کم‌تر از مقیاس ماهانه است که نشان‌دهنده نتایج دقیق‌تر مدل‌سازی روزانه نسبت به ماهانه است. نتایج مربوط به سری زمانی صحت‌سنجی در شکل (۴) نشان داده شده است.

۴- نتیجه‌گیری

همان‌طور که در شکل (۴) نشان داده شده، مقایسه بین دو روش حاکی از آن است که عرض PI در روش LUBE از روش بوت‌استرپ کم‌تر بوده که نشان‌دهنده عملکرد بهتر و قابلیت اطمینان بیشتر این روش است و نتایج حاصل با برخی مطالعات گذشته همچون (Kasiviswanathan و Tormina، ۲۰۱۵؛ Chau، ۲۰۱۵؛ Sudheer و Tormina، ۲۰۱۶) مطابقت دارد. مقادیر PICP برای روش LUBE در شش مدل ANN از هشت مدل، بیشتر از بوت‌استرپ می‌باشد. مقادیر NMPIW پنج مدل از میان هشت مدل، برای روش بوت‌استرپ بیشتر از روش LUBE است که نشان‌دهنده عدم قطعیت بیشتر PI‌های ساخته‌شده با استفاده از روش بوت‌استرپ بوده است.

همان‌طور که در شکل (۴) نشان داده شده است، اگرچه روش بوت‌استرپ در مقایسه با روش LUBE، PI‌های گسترده‌تری را ایجاد می‌کند اما در تخمین نقاط اوج رواناب عملکرد بهتری دارد و همچنین در اکثر موارد مقادیر رواناب بیش برآورد شده است. علت این عملکرد شاید به دلیل انتخاب تصادفی نمونه‌ها در آموزش ANN‌ها در روش بوت‌استرپ باشد و همچنین زیرمجموعه‌های تصادفی انتخاب‌شده برای آموزش شامل خصوصیت‌های آماری داده‌های اصلی نباشد (Nourani و همکاران، ۲۰۱۹). همچنین با توجه به نمودارهای شکل (۴)، مقادیر مشاهداتی به حد بالای پیش‌بینی نزدیک‌تر هستند که حاکی از ریسک بالای مدل‌سازی فرایند بارش و رواناب بوده است در مطالعات گذشته مانند

اگرچه مدل‌سازی هیدرولوژیک مبتنی بر ANN به‌طور گسترده در پیش‌بینی نقطه‌ای بارش و رواناب به‌کار می‌رود، اما پیش‌بینی نقطه‌ای ANN هیچ اطلاعاتی درباره دقت پیش‌بینی نمی‌دهد، بنابراین PI‌ها در کمیت‌سنجی قابلیت اطمینان مدل‌سازی بسیار مهم است.

در این مقاله مدل‌سازی بارش و رواناب مبتنی بر ANN برای دو حوضه ليقوان چای و نیشناپوتنا، در دو مقیاس روزانه و ماهانه انجام شده است. PI‌ها با روش LUBE که مبتنی بر ANN با دو خروجی که نشان‌دهنده حد بالا و پایین هستند، محاسبه شدند. همچنین از روش بوت‌استرپ برای ساخت PI‌ها استفاده شد و نتایج حاصل از دو روش با دو معیار همگرایی و عرض فواصل مقایسه گردید. نتایج نشان داد که PI‌های ایجادشده با روش LUBE نسبت به روش بوت‌استرپ قابل اطمینان‌تر بوده‌اند و با توجه به این که این روش، PI‌هایی با عرض کم‌تری ایجاد کرده است عدم قطعیت کم‌تری را شامل شد و PICP تا ۲۰٪ برای PI‌های ساخته‌شده با استفاده از روش LUBE بیشتر از PI‌های ساخته‌شده با استفاده از روش بوت‌استرپ است. همچنین مدل‌سازی روزانه نسبت به ماهانه دقت بیشتری در هر دو روش داشت و مقدار PICP تا ۲۹٪ و ۲۱٪ به ترتیب در رودخانه ليقوان چای و رودخانه غرب نیشناپوتنا با مدل‌سازی در مقیاس روزانه در مقایسه با مدل‌سازی در مقیاس ماهانه بیشتر بود. مقایسه نتایج برای دو حوضه

- method", *Water Resources Management*, 2015, 29 (13), 4863-4883.
- Khosravi A, Nahavandi S, Creighton D, "A prediction interval-based approach to determine optimal structures of neural network metamodels", *Expert Systems with Applications*, 2010, 37 (3), 2377-2387.
- Khosravi A, Nahavandi S, Creighton D, Atiya AF, "Lower upper bound estimation method for construction of neural network-based prediction intervals", *IEEE Transactions on Neural Networks*, 2011, 22 (3), 337-46.
- MacKay DJC, "A practical Bayesian framework for backpropagation networks", *Neural Computation*, 1992, 4 (3), 448-472.
- Nourani V, Kisi Ö, Komasi M, "Two hybrid artificial intelligence approaches for modeling rainfall-runoff process", *Journal of Hydrology*, 2011, 402 (1-2), 41-59.
- Nourani V, Khanghah TR, Baghanam AH, "Application of Entropy Concept for Input Selection of Wavelet-ANN Based Rainfall-Runoff Modeling", *Journal of Environmental Informatics*, 2015, 26 (1).
- Nourani V, Paknezhad NJ, Sharghi E, Khosravi A, "Estimation of prediction interval in ANN-based multi-GCMs downscaling of hydro-climatologic parameters", *Journal of Hydrology*, 2019, 579, 124226.
- Quan H, Srinivasan D, Khosravi A, "Particle swarm optimization for construction of neural network-based prediction intervals", *Neurocomputing*, 2014, 127, 172-180.
- Riad S, Mania J, Bouchaou L, Najjar Y, "Predicting catchment flow in a semiarid region via an artificial neural network technique", *Hydrological Processes*, 2004, 18 (13), 2387-2393.
- Shannon CE, "A mathematical theory of communication", *Bell System Technical Journal*, 1948, 27 (3), 379-423.
- Sharghi E, Nourani V, Najafi H, Gokcekus H, "Conjunction of a newly proposed emotional ANN (EANN) and wavelet transform for suspended sediment load modeling", *Water Supply*, 2019, 19 (6), 1726-34.
- Srivastav RK, Sudheer KP and Chaubey I, "A simplified approach to quantifying predictive and parametric uncertainty in artificial neural network hydrologic models", *Water Resources Research*, 2007, 43 (10).
- Sudheer KP, Gosain AK, Ramasastri KS, "A data-driven algorithm for constructing artificial neural network rainfall-runoff models", *Hydrological Processes*, 2002, 16 (6), 1325-1330.
- Tiwari MK, Chatterjee C, "Uncertainty assessment and ensemble flood forecasting using bootstrap based artificial neural networks (BANNs)", *Journal of Hydrology*, 2010, 382 (1-4), 20-33.
- Taormina R, Chau KW, "ANN-based interval forecasting of streamflow discharges using the LUBE method and MOFIPS", *Engineering Applications of Artificial Intelligence*, 2015, 45, 429-40.
- Yang HH, Van Vuuren S, Sharma S, Hermansky H, "Relevance of time-frequency features for phonetic and speaker-channel classification. *Speech communication*", 2000, 31 (1), 35-50.
- Zio E, "A study of the bootstrap method for estimating نشان‌دهنده عملکرد بهتر مدل‌سازی در حوضه ليقوان‌چای در مقایسه با رودخانه غرب نیشناپوتنا بود و PICIP برای PI‌های ساخته‌شده برای این حوضه تا ۲۱٪ بیشتر از آن برای حوضه رودخانه غرب نیشناپوتنا بود و علت عملکرد بهتر مدل‌سازی در حوضه ليقوان‌چای به دلیل چهار فصل منظم در این حوضه است. با توجه به این‌که در این مطالعه دسته وزن‌های تولیدشده برای ساخت PI به صورت تصادفی می‌باشد پیشنهاد می‌شود در مطالعات آتی از روش‌های تکامل تدریجی مانند الگوریتم ژنتیک برای ایجاد دسته وزن‌های بهینه استفاده شود.
- ### ۵- مراجع
- رجایی ط، زینی‌وند ا، "مدل‌سازی تراز آب زیرزمینی با بهره‌گیری از مدل هیبرید موجک- شبکه عصبی مصنوعی (مطالعه موردی: دشت شریف‌آباد)", *نشریه مهندسی عمران و محیط زیست دانشگاه تبریز*، ۱۳۹۳، ۴۴ (۴)، ۵۱-۶۳.
- ندیری ع، واحدی ف، اصغری‌مقدم ا، کدخدایی ع، "استفاده از مدل هوش مصنوعی مرکب نظارت شده برای پیش‌بینی سطح آب زیرزمینی"، *نشریه مهندسی عمران و محیط زیست دانشگاه تبریز*، ۱۳۹۵، ۴۶ (۳)، ۱۰۱-۱۱۲.
- Chryssolouris G, Lee M, Ramsey A, "Confidence interval prediction for neural network models", *IEEE Transactions on Neural Networks*, 1996, 7 (1), 229-232.
- Dhanesh Y, Sudheer KP, "Predictions in ungauged basins: can we use artificial neural networks", *American Geophysical Union Joint Assembly, Foz Doiguassu, Brazil*, 2010, August 8-13.
- Efron B, Tibshirani RJ, "An introduction to the bootstrap", *CRC press*, 1994.
- Gao Z, Gu B, Lin J, "Monomodal image registration using mutual information based methods", *Image and Vision Computing*, 2008, 26 (2), 164-173.
- Grant EL, Leavenworth RS, "Statistical quality and control New York", *McGraw-Hill*, 1972, 643.
- Hagan MT, Menhaj MB, "Training feedforward networks with the Marquardt algorithm", *IEEE Transactions on Neural Networks*, 1994, 5 (6), 989-993.
- Imrie CE, Durucan S, Korre A, "River flow prediction using artificial neural networks: generalisation beyond the calibration range", *Journal of Hydrology*, 2000, 233 (1-4), 138-153.
- Kasiviswanathan KS, Sudheer KP, "Quantification of the predictive uncertainty of artificial neural network based river flow forecast models", *Stochastic Environmental Research and Risk Assessment*, 2013, 27 (1), 137-146.
- Kasiviswanathan KS, Sudheer KP, "Comparison of methods used for quantifying prediction interval in artificial neural network hydrologic models", *Modeling Earth Systems and Environment*, 2016, 2 (1), 2-22.
- Kumar S, Tiwari MK, Chatterjee C, Mishra A, "Reservoir inflow forecasting using ensemble models based on neural networks, wavelet analysis and bootstrap

the accuracy of artificial neural networks in predicting nuclear transient processes", IEEE Transactions on Nuclear Science, 2006, 53 (3),1460-1478.

EXTENDED ABSTRACT

Estimation of Prediction Intervals for ANN- Based Rainfall- Runoff Modeling

Elnaz Sharghi*, Nardin Jabbarian Paknezhad

Faculty of Civil Engineering, University of Tabriz, Tabriz 5166616471, Iran

Received: 29 May 2019; Accepted: 12 November 2020

Keywords:

Rainfall-Runoff, Prediction interval, Artificial Neural Network, Bootstrap, Lighvanchai river, West Nishnabotna river.

1. Introduction

In this study, Lower Upper Bound Estimation (LUBE) method, which was firstly introduced by Khosravi et al. (2010) and is a novel PIs construction method in hydrologic issues, is applied to construct PIs for ANN-based rainfall-runoff modeling. This technique is independent of any knowledge about the bounds of PIs or data distribution. The ANN-based LUBE method includes two outputs showing upper and lower bounds of prediction in contrast to the classic ANNs, which consider one output as point prediction. In this way, dominant input data combination is selected by the mutual information (MI) to the model rainfall-runoff process in both monthly and daily scales for two different watersheds in Iran and USA. Finally, the obtained PIs by the proposed LUBE method are compared with those obtained by the classic Bootstrap method.

2. Methodology

2.1. Study area and data set

In this paper, the data from two watersheds with various geomorphology were considered for the modeling, West Nishnabotna River (a sub-basin of Missouri River in the United States) and Lighvanchai River (a sub-basin in Iran). The first set of data used in this paper is for the Lighvanchai watershed located in northwest Iran at Azerbaijan province. The time series data was obtained from Iran Water & Power Resources Development Co. (IWPC) for the Lighvan station. This watershed is one of the main sub-tributaries of the Ajichai River, which discharges to Urmia Lake. Lighvanchai watershed is located between 37° 43' and 37°50' North latitude and 46°22' and 46°28' East longitude in the northern slope of Sahand Mountain (northwestern Iran). The watershed area is approximately 142 km². The second study area, the West Nishnabotna River watershed, is the main sub-basin of the Missouri River watershed that is located in southwestern Iowa. The river is placed at the longitude and latitude coordinates of 95° 67' W and 40° 51' N and the longest stream length of this river is about 190 km in Randolph station. For the study period, monthly and daily data were extracted from the waterwatch.usgs.gov website.

2.2. PIs construction by LUBE method

The structure of ANN with two outputs for estimating upper and lower bounds of PIs via the LUBE method is shown in Fig. 1. The first output corresponds to the upper bound and the second stands for the lower bound. In the first step, the data set is split into training and validation subsets, then an ANN with two outputs (optionally for initial values of outputs, ±5% of observed values can be considered to train ANN and find initial guesses for the weights). Then weights are randomly perturbed around the initial weights to generate some

* Corresponding Author

E-mail addresses: sharghi@tabrizu.ac.ir (Elnaz Sharghi), n.jabbarian@tabrizu.ac.ir (Nardin Jabbarian Paknezhad).

new weight sets. Dhanesh and Sudhear (2011) have reported that ANN weights are sensitive in a range of $\pm 10\%$ from the calibrated values, therefore some new ANNs with the several sets of perturbed weights (in the range of $\pm 10\%$ around initialized weights) are created and ANNs are simulated with these weight sets to obtain different sets of PIs.




Fig. 1. ANN model for estimating upper and lower bounds of PIs (Quan et al. 2014)

2.3. PIs construction by Bootstrap method

Efron and Tibshirani (1993) developed the Bootstrap method, which resamples the training datasets for the purpose of generating various models by training an individual network on each resampled instance of the original dataset. The positive point about the application of this technique is that it does not require complex derivatives of any non-linear function.

3. Results and discussion

3.1. Results of point prediction by ANN model

Eight ANNs with different inputs were trained in this study on monthly and daily scales. The used time series as inputs of ANN were tabulated in Table 1. For calibration and validation of the ANNs, the data set was split into two parts, 75% of the data were used to train and the rest 25% were used to validate. Therefore, the data in periods 1981-2007 and 1987-2005 were used for the training, respectively for Lighvanchai and West Nishnabotna River and in periods 2007-2015 and 2005-2015 for the validation purpose. The obtained results of point prediction were tabulated in Table 1.

Table 1. Point prediction results for two watersheds in both daily and monthly scales

Scale	Basin	ANN	input	NSE train	NSE verification	R train	R verification	RMSE train	RMSE verification
Daily	Lighvanchai	1	$I_t, Q_{t-1}, Q_{t-2}, Q_{t-3}$	0.81	0.72	0.9	0.84	0.007	0.01
		2	$Q_{t-1}, Q_{t-2}, Q_{t-3}$	0.93	0.9	0.96	0.95	0.02	0.03
	West Nishnabotna River	3	I_t, Q_{t-1}, Q_{t-2}	0.56	0.54	0.75	0.75	0.02	0.03
		4	$Q_{t-1}, Q_{t-2}, Q_{t-3}, Q_{t-4}, Q_{t-5}$	0.7	0.7	0.84	0.83	0.02	0.03
Monthly	Lighvanchai	5	$I_{t-1}, Q_{t-1}, Q_{t-2}$	0.71	0.64	0.84	0.8	0.07	0.08
		6	$Q_{t-1}, Q_{t-2}, Q_{t-3}, Q_{t-12}, Q_{t-13}$	0.84	0.66	0.92	0.8	0.05	0.08
	West Nishnabotna River	7	$I_{t-1}, Q_{t-1}, Q_{t-2}$	0.55	0.5	0.67	0.69	0.08	0.1
		8	$Q_{t-1}, Q_{t-2}, Q_{t-12}, Q_{t-13}$	0.5	0.5	0.69	0.7	0.08	0.1

3.2. Results of PIs construction using LUBE and Bootstrap methods

The overall performance of any PIs construction method for ANN-based modeling depends on the network structure and training process. To obtain the most accurate results, the optimum number of neurons was determined by trial and error, and in this way, 1 to 12 numbers of neurons were checked by trial and error. The confidence level associated with all PIs was considered as 90%. Two criteria, PICP (Eq.1) and NMPIW (Eq. 2), were computed for each generated set of the weights (by perturbation of initialized weights) to find out the

optimum structure of ANN for constructing the PIs (with a maximum value of PICP and minimum value of NMPIW). The obtained optimal PICP and NMPIW values in constructing the PIs are presented in Table 2.

$$PICP = \frac{1}{N} \sum_{i=1}^N c_i \quad \text{if} \quad L(X_i) < x_i < U(X_i) \rightarrow c_i = 1 ; \text{else} \rightarrow c_i = 0 \quad (1)$$

$$NMPIW = \frac{1}{Rn} \sum_{i=1}^n L(X_i) - U(X_i) \quad (2)$$

Table 2. Constructed PIs results for both watersheds via LUBE and Bootstrap methods

Scale	ANN model	LUBE		Bootstrap	
		PICP	NMPIW	PICP	NMPIW
daily	1	0.86	0.04	0.6	0.09
	2	0.93	0.25	0.89	0.11
	3	0.88	0.05	0.77	0.03
	4	0.74	0.04	0.72	0.02
Monthly	5	0.69	0.17	0.6	0.19
	6	0.56	0.1	0.83	0.3
	7	0.7	0.17	0.51	0.11
	8	0.73	0.14	0.75	0.18

4. Conclusions

In this paper, ANN-based modeling, for rainfall-runoff modeling for two watersheds of Lighvanchai and West Nishnabotna River, was carried out in monthly and daily time scales. The PIs of the predictions were constructed using the LUBE method, via an ANN with two outputs representing upper and lower bounds of the PIs. For quantitatively evaluating the performance of the constructed PIs, NMPIW and PICP criteria were computed for all models. The obtained results were then compared with the results of the classic Bootstrap method. Analysis indicated that daily scale modeling led to more reliable results in both PIs construction methods. Values of PICP, respectively, were up to 29% and 21%, higher in daily scale compared to monthly scale for constructed PIs of Lighvanchai and West Nishnabotna River basin modeling. It was concluded that the LUBE method could build narrow PIs with higher PICP, values of PICP and NMPIW respectively, for constructed PIs via LUBE method were up to 20% higher and 30% lower than those constructed via the Bootstrap method, which denoting to the superiority of LUBE method with regard to the Bootstrap method. Comparison between the performance of the two basins, indicated that Lighvanchai showed better performance compared to West Nishnabotna River basin, PICP values for constructed PIs of Lighvanchai basin modeling were up to 21% higher than those for West Nishnabotna River basin. The regular four seasons for the Lighvanchai basin causes the better performance of its modeling.

5. References

- Efron B, Tibshirani RJ, "An introduction to the bootstrap", CRC press, 1994.
- Khosravi A, Nahavandi S, Creighton D, "A prediction interval-based approach to determine optimal structures of neural network metamodels", Expert systems with applications, 2010, 37 (3), 2377-2387.
- Quan H, Srinivasan D and Khosravi A, "Particle swarm optimization for construction of neural network-based prediction intervals", Neurocomputing, 2014, 127, 172-180.